

(Trefethen-Bau, Lekcia 31)

Výpočet SVD rozkladu libovolnej matice sa dá zrealizovať na výpočet spektrálneho rozkladu ľavovocnej hermitovej matice, ale najviac náskajúci sa spôsob nie je stabilný. Treba použiť inú redukciu na SVD, čo vedie k ~~čiže~~^(implicitne) unitnej ~~bidiagonálizácii~~ v prvej fáze.

SVD matice A a s. hodnoty A^*A

Singulárny rozklad matice $A = \underset{m \times n}{U} \Sigma V^*$ ($m \geq n$)

súvisí so spektrálnym rozkladom matice A^*A

$$A^*A = V \Sigma^* \Sigma V^*$$

Ze toho by sme (matematicky) vedeli vypočítať SVD nasledovne:

1. vytvoriť A^*A

2. najst spektrálny rozklad $A^*A = V \Delta V^*$

3. Σ je množina nezáporných diagonálnych odmociniek z Δ .

4. najst riešenie $A = U \Sigma V^*$, kde U je unitná.

Takýto algoritmus sa používa (aj keď som pri výpočte SVD v alkohole prie rozlúčne odhadly, ...), ale ako pišu v knihe – používajú ho "Kodia čo si samo-objavili SVD que sera".

Matice A^*A - kovariančná matice A , resp. gramova matice má známe upozitie v statistike a mode.

Takýto algoritmus je veľmi nestabilný, lebo

pridružený problém je hľadáť jeho ťažky na perturbáciu.

Problém je v nasledovnom:

A) perturbujeme hermitovskú $A^*A + \delta B$, potom

$$|\lambda_k(A^*A + \delta B) - \lambda_k(A^*A)| \leq \|\delta B\|_2$$

Ako vidime neskôr, podobný vzťah platí aj pre singulárne hodnoty

$$|\sigma_k(A + \delta A) - \sigma_k(A)| \leq \|\delta A\|_2.$$

Späťe stabilny algoritmus pre singulárne hodnoty by daval:

$$\tilde{\sigma}_k = \sigma_k(A + \delta A) \quad \text{pre } \frac{\|\delta A\|}{\|A\|} = O(\epsilon_{\text{machine}})$$

teda $|\tilde{\sigma}_k - \sigma_k| = O(\epsilon_{\text{machine}} \|A\|)$.

— Ak by sme vziať polovičné (stabilné) $\lambda_k(A^*A)$, nazme:

$$|\tilde{\lambda}_k - \lambda_k| = O(\epsilon_{\text{machine}} \|A^*A\|) = O(\epsilon_{\text{machine}} \|A\|^2)$$

Kedže $\sigma_k = \sqrt{\lambda_k}$, teda

$$|\tilde{\sigma}_k - \sigma_k| = O(|\tilde{\lambda}_k - \lambda_k|/\sqrt{\lambda_k}) = O(\epsilon_{\text{machine}} \|A\|^2/\sigma_k)$$

čiže vtedy je $O(\|A\|/\sigma_k)$.

Pre veľké $\sigma_k (\approx \|A\|)$ to problém nie je,

pre $\sigma_k \ll \|A\|$ význam. ďalo.

Teda $\frac{1}{\sigma_k} = \|A\|^{-1}$, teda

Pre najmenšiu σ_n nazme $\|A\|^2/\sigma_n$ bude $\|A\| - \|A\|^2/\sigma_n = \alpha A$.

— teda nazme stratu prenosu na ulomku $\alpha(A)$.

Čo zodpovedá "štvorcu súčtu podmienenosťí" pre normálne
romice pri najmenších štvorcoch

$$\begin{aligned} Ax &= b & \sim k(A) \\ A^*Ax &= A^*b & \sim k(A)^2. \end{aligned}$$

Iná redukcia na hermitovskú matice

Existuje viac tried, stabilnejší, spísob, ako preiesť SVD rozklad na problem spektrálneho rozkladu:
 pre jednoduchosť, nech $m=n$ a A je ťažcová
 (to nebude problem, ale určite neskôr).
 Uvažujme $2m \times 2m$ ^{hermitovskú} maticu:

$$H = \begin{bmatrix} 0 & A^* \\ A & 0 \end{bmatrix}.$$

Keďže $A = U\Sigma V^*$, tak $AV = U\Sigma$ a aj $A^*U = V\Sigma^* = V\Sigma$

Teda

$$\begin{bmatrix} 0 & A^* \\ A & 0 \end{bmatrix} \begin{bmatrix} V & V \\ 0 & -V \end{bmatrix} = \begin{bmatrix} V & V \\ 0 & -V \end{bmatrix} \begin{bmatrix} \Sigma & 0 \\ 0 & -\Sigma \end{bmatrix}.$$

Lene to je spektrálny rozklad matice H .

→ singulárne hodnoty A sú teda abs. hodnoty matice H , t. j. sing.
 vektor A sa dajú zistíť z vš. vektorov pre H .

SVD rozklad A teda vieme získať prechodom k matici H
 a každejmu jej spektrálneho rozkladu. Toto, na vychiel od počítania
 s A^*A bude stabilné.

Standardné SVD algoritmy viaž s maticou H prebieha len
 implicitne. → ešte žiadne matice typu $(m+n) \times (m+n)$ sa
 nevoria.

Proces sa chce výkonat ujchlo \rightarrow no tiež 1 sa spravi
 redukcia na bidiagonálny tvor.

Dve fázy

podobne ako pre problém rel. hodnoty hermitovej matice sú tie podobné ako pre problém rel. hodnoty hermitovej matice sú mali dvojfaktorový výpočet, \Leftrightarrow (redukcia na tri-diag. tvr, diagonálitu až tri-diagonálnu).

Od 60-tých rokov (Golub, Kahan, etc) ~~existuje~~ sa podobný dvoj-faktorový prístup používa aj pre SVD.

$$\begin{array}{c}
 \left[\begin{array}{cccccc} x & x & x & x & & \\ x & x & x & x & & \\ x & x & x & x & x & \\ x & x & x & x & x & \\ x & x & x & x & x & \\ x & x & x & x & x & \end{array} \right] \xrightarrow{\text{Fáza 1}} \left[\begin{array}{ccccc} x & x & & & \\ & x & x & & \\ & & x & x & \\ & & & x & x \\ & & & & x \end{array} \right] \xrightarrow{\text{Fáza 2}} \left[\begin{array}{ccccc} y & & & & \\ & x & x & & \\ & & x & & \\ & & & x & \\ & & & & x \end{array} \right] \\
 A \qquad \qquad \qquad B \qquad \qquad \qquad \Sigma
 \end{array}$$

↑
bidiagonálna.

Fáza 1 si vyžaduje konečný počet operácií - $O(n^2)$ flopov.

Fáza 2 si (teoreticky) vyžaduje nekonečný počet operácií, ale v dôsledku superlineárnej konvergencie stačí

$$O(n \log(\lceil \log(\epsilon_{\text{tolerancia}}) \rceil)) \text{ iterácií, t.j. } O(n)$$

ak $\epsilon_{\text{tolerancia}}$ je konštantou, na človek prenosí $\epsilon_{\text{tolerancia}}$, ak $\epsilon_{\text{tolerancia}}$ je konštantou, na človek prenosí $\epsilon_{\text{tolerancia}}$.

v dôsledku bidiagonálnosti v každej iterácii potrebujeme len $O(n)$ flopov - spolu v fáze 2 $O(n^2)$ flopov, (ak sa počítajú len singulárne hodnoty a nie vektory)

Teda Fáza 1 je konečná, fáza 2 je princípe nekonečná, ale v praxi typickým ovplyvňovať faktorom je, podobne ako pre problém rel. hodnoty v symetrickom prípade.

Golub-Kahan bidiagonálizácia

4.3

Vôz faze 1 sa A prevedie na bidiagonálnu matice pomocou rôznych unitárnych operácií zľava a sprava.
Na rozdiel od výpočtu r.v. hodnot, kde sú potrebovali vomáre unitárne operácie z obidvoch strán, tu stácia viac.

Analógia

Takto vieme dostať nuly nielen na spodnú vedľajšiu diagonálu, ale aj nad ~~na~~ prvú horú vedľajšiu.

Najjednoduchšie to ide pomocou Golub-Kahan bidiagonalizácie:

- Householderove reflektory sa striedavo používajú sprava a zľava. každý ľavý reflektor vytvára nuly pod diagonálou, zatiaľ čo pravé vytvára nuly na pravu od priej hornej vedľajšej diagonály (alkopniecky).

Priklad:

$$\begin{array}{c} \left[\begin{array}{ccccccccc} X & X & X & X \\ X & X & X & X \\ X & X & X & + \\ X & X & X & X \\ X & X & X & X \\ X & X & X & X \\ X & X & X & + \end{array} \right] \xrightarrow{U_1^*} \left[\begin{array}{ccccccccc} X & X & X & X \\ 0 & X & X & X \end{array} \right] \xrightarrow{V_1} \left[\begin{array}{ccccccccc} X & X & 0 & 0 \\ 0 & X & X & X \end{array} \right] \\ A \qquad U_1^* A \end{array}$$

$$\xrightarrow{U_2^*} \left[\begin{array}{ccccc} X & X \\ X & X & X & X \\ 0 & X & X \\ 0 & X & X \\ 0 & X & X \end{array} \right] \xrightarrow{V_2} \left[\begin{array}{ccccc} X & X \\ X & 0 \\ X & X \\ X & X \\ X & X \end{array} \right]$$

Ľavé usadenie U_1^* mení viacky 1 na 0, vytvára nuly v premenej pod diagonálou.

pravé násobenie V_1 nemá stĺpce $2 \dots n$, vytobi uhy
v riadku 1, za čo bez toho aby pokazilo prvy stĺpec s nulami.

Aždá - riadky $2 \dots n$, stĺpce $3 \dots n$, ...

V rámci tohto procesu sa použije n reflektorov zíara
a $n-2$ sprava.

Pri analýze počtu floporov to teda vyzera tak, akoby
sme využili ~~dvore preplňené~~ Householderovskú QR redukciu na maticu
 A typu $m \times n$ (zíara) a na maticu $n \times n$ A^* (sprava)


→ Lekcia 10 →

počet floporov pre Golub-Kahan $\sim 4mn^2 - \frac{4}{3}n^3$ flopor.

Fáza 1 sa dá uvoľniť ...

Ak $m \gg n$, toto je náročne pôsobivé. Väčšina miest sa
totož nachádzajú pod diagonálou a tie vieme dosiahliť QR
rozkladom matice A .

(Lawson-Hanson + Chan) : LHC - bidiagonálizácia



Zároveň sa s QR rozkladom $A = QR$ a postam sa správnej
Golub-Kahan bidiagonálizáciu matice R , $B = U^* R V$.

- QR potrebuje $2mn^2 - \frac{2}{3}n^3$ flopor,


Golub-Kahan na $n \times n$ matici R len potrebuje $\frac{8}{3}n^3$ flopor. \rightarrow LHC

Toto bude efektívnejšie ako Golub-Kahan ak $m > \frac{5}{3}n$. 4.4

Zaujímavosťou je, že LHC vytvára muly (po diagonále) a potom ich počasí, keď vytvára muly napravo od nej.

LHC sa opakuje iba ak $m > \frac{5}{3}n$, ale myšlienka sa dať použiť aj pre iné $m > n$. Tík spôsobu ťaženia, že QR rozklad používaný ešte v levoštvajúcej faze.

Začнемe s Golub-Kahan, ktorý z iných miest vytvára $(m-k) \times (n-k)$ podmatrix so správnym pomelcom, potom sa preprave do miestu LHC



→ počet operácií bude minimálny pri pomere $\frac{m-k}{n-k} = 2$,

pričom takéto troj-kroková bidiagonálizácia bude stať

$$\sim 4mn^2 - \frac{4}{3}n^3 - \frac{2}{3}(m-n)^3 \text{ flpwr.}$$

- miene zlepšenie pre $n \leq m \leq 2n$.

Fáz 2

Tu sa robí iteratívny upozdňovací SVD pre bidiagonálnu matice, podobný ako QR algoritmus (80-te - 90-te roky).

Neskôr uvažuje divide-and-conquer, ktorý pomerne podobne pre väčšie matice bude standardný.. Bez detaľov.

Prehľad iteratívnych metód

→ tejto kapitole sa presúvame tematicky od priamyx metód vypočítav (ktoré sú pomerne ustálene) k iteratívnym metódam, kde je to ešte stále "divoké". Napriek tomu, toto je budúcnosť ...

Prečo iterovať?

dlhým časom preto uprednostňujeme iteratívne metódy je zložitosť. Neiteratívne, priame metódy typicky stojí $O(m^3)$ operácií. To je rozh. pre matice ($\leq O(m^2)$ drahým vstupom) možno priviesť.

Nehovoriac o tom, že m^3 je veľmi obrovské pre veľké m .

Historia "obrovskosti"

1950	$m = 20$
1965	$m = 200$
1980	$m = 2000$
1995	$m = 20000$
2010 (?)	$m = ?$

→ toto sú príklady z dobovej literatúry pre "velmi veľke" hukťe matice pre priame vypočty.

Ako sme už spomneli pred päť rokmi, za 45 rokov m vrástilo 10^3 krát, ale kapacita počítačov cez 10^9 krát.

→ Čo ukazuje na "bottleneck" - úzkky profil $O(m^3)$ $(10^{12}?)$ priamyx vypočtor.

Ak by sme viedli efektívnu veci $O(m^2)$, tak námene zlepšenie 10 zo 100 krát.

Štruktúra, hmotnosť, ďierne skrinky

4.5

To, či sa dá $O(n^3)$ zložitosť parazit niesť je jasné.

Pre ľahšiej maticový problém to asi nepôjde.

Treba sa však zamyslieť nad tým odkiaľ pochádzajú veľké maticové výpočty.

"malé matice", 3 až 30 miest pochádzajú z ľubovoľných interakcií 3 súborov, či 30-tich subpopulačí - t.j. maticu musíme vypočítať bez nejakej štruktúry.

Veľké matice sa však vyskytujú nepriame - ako diskretizácia spojitého problému (PDR alebo integratívne ronice)

- ak je tu veľké, ide o aproximáciu nekončnej.

V tom prípade majú veľké matice jednoduchú štruktúru, ktorá sa dá využiť.

Zjavná štruktúra je niedkosť (opäť hustosť)

Napr. konečná diskretizácia pomocou diferenciálov pre PDR možno viesť k matici s $m=10^5$ ale iba $N=10$ nenulových zložiek v riadku:



To sa dá využiť pri iteratívnych metódach, ktoré využívajú maticové násobenia do "čiernej skrinky"

$$x \rightarrow \boxed{\text{BLACK}} \rightarrow Ax.$$

Teda oddeliťme iteratívny algoritmus od násobenia maticov, ktoré bude následne samostatnej procedúrou, ktorej detaility nemusíme poznáť.

(niekedy treba poznáť aj súčin A^*x)

Napr. pre nieku malicu sa dá najsť metóda výpočtu Ax , ktorá potrebuje len $O(\sqrt{m})$ operácií namiesto $O(m^2)$.

Toto je veľký rozdiel oproti priamyu metódam

(Gaušova eliminácia / LU- rozklad, Choleskeho rovnice triangulizácia) QR- rozklad.

ktoré pracajú priamo so zložkami matice A.
manipuluju

- tiež vyrábajú nuly, ale musia pokračovať viedkost.

Historicky, viedkost bola dominantnou druh struktúry.

Pri súčasnom maximum zbere dát sa vžahl užíva
objavovať iný typ - ~~tedy~~ matice budú husto, ale
dáta v nich budú mať repetívny charakter - teda
budú v sebe obsahovať istú regularitu.

Ta sa dá zachyliť pomocou Fourierovej transformácie,
wavelet expanzii či "multipole" metód.

→ posom "black box" metódy môžu byť dosť sofistikované...

Projekcie na krylovové podpriestory

Myslenie iteratívnych metód je založené na projekcii
m-variantného problému na nízorozmerný krylovový priestor.

Pre maticu A a vektor b bude postupnosť

$b_1, Ab_1, A^2b_1, A^3b_1, \dots$ ktorú vieme dostať pomocou

čiernej skriby ako $b_1, A(b_1), A(A(b_1)), A(A(A(b_1))), \dots$
krylovova postupnosť.

Příslušné krylové podprostory sú generované
prvými k-členmi tejto postupnosti.

4.6

Budeme sa venovať týmto algoritmom:

$$Ax = b \quad Ax = \lambda x$$

$$A = A^*$$

Lanczos

$$A \neq A^*$$

Arnoldi

CG
(zduž. gradienty)

GMRES,
CGN,
BCG

zduž. gradienty
pro normálosť

generalized minimal residuals

biconjugate gradients

V každej z týchto metod budeme počítavať problem

redukovať na malicové problémy dimenzia $n=1, 2, 3, \dots$

Počet Hermitovské matice A budeme mať redukované
matice triadiagonálne, pre nehermitovské \rightarrow budú v
Hessenbergovej forme.

- Arnoldiho algoritmus počíta v. hodnoty ~~pomočou~~ pomocou v. hodnot
nejakyh Hessenbergových matíc väčších dimenzia.

Počet krokov, počet operácií v kroku, predpriprava (preconditioning)

Gaušova eliminácia, QR rozklad a iné algoritmy "huslej"
lineárnej algebre majú zloženosť $O(n^3)$ - majú $O(n)$ krokov,
keďže s $O(n^2)$ veľa práce - operáciami.

Pre iteratívne metódy toto bude pravda, ale iba v najkoršom
prípade. Keď sú iteratívne metódy rýchlesie, budeme ~~vysk~~
vedieť redukovať obecne tiež zložky.

- Počet krokov potrebných do konvergencie bude, v súčinnosti
smyšle slova, závisieť od spektrálnych vlastností A

metoda
Napr. zdrobených gradientov pre riešenie kl. definitného
determinantného systému $Ax=b$ bude konvergovať rýchlo,
ak sú vš. hodnoty zhrávateľne od 0,
(sú reálne, kladné...)

Podobne Lanczosov algoritmus dá niektoré vš. hodnoty
reálnej Hermitovej matice, ak sú dobre oddelené od zvyšku spektra.
(+ startovný vektor je dostatočne generický).

-> využíva súčinor S approximáciami funkcií $f(z)$ polynomiálnimi
 $p(z)$ na ~~reálnej~~ ^{častiach} vš. alebo na komplexnej rovine.

Mužstvo práce v jednom kroku závisí od struktúry matice
a ako vie túto struktúru využiť čierna skriňa
hásiacia $x \mapsto Ax$.

Ideálna metoda vypočíta počet krokov $\approx O(n)$ na $O(1)$
a práca v kroku $\approx O(n^2)$ na $O(n)$ (dlžka vektora)
- čím zväčšíme celkovú náročnosť $\approx O(n^3)$ na $O(n)$.

Takéto zvýšenie sa niekedy náročnej dát dosiahliť, ale
typicky sa dosahuje zlepšenie $O(n^3) \rightarrow O(n^2)$.

V 90-tých rokoch to znamenalo 10-káslové zvýšenie
oproti priamym algoritmom.

Pri zváčšovaní m uskôr tento rozdiel bude narastať -
a uženam iteratívnych algoritmov vzastie:

Základný zákon Computer Science:

čím rýchlejší počítač, tým väčšia uženam/dôležitosť
rýchlosťi algoritmu

Precné vs. približné riešenie

4.7


Iteratívne metódy sú približné v tom zmysle, že v princípe by na prvoty výsledok podrobali nekonečne veľa krokov v prenej aritmetike. (bez zaokruhľovania chyb).

Toto zvykne "zaciatočníkom" vieda ... lebo majú pocit, že iterovanie je len taká inžinierčina bez elegancie pochybnnej spôsobilosti. Chce to väčšinou "priťhať na chut".

Koniec-koncov, vo floating point aritmetike sú aj priame metódy len približné a najviac v čo užívame dôfakt je strojová presnosť.

Kedže iteratívne metódy vedú takúto presnosť dosiahnuť, nereba sa zbyť vobec zbytočné stavosti.

A elegancia bude tiež ...



Konvergencia priamyx a iteratívnych metod
- geometrická konvergencia pod presnosť ϵ -mádnu
vs. $O(n^3)$ poist kroky, ktoré upozorňajú, čo niečo všetko.

Priame metody ležíce ako $O(n^3)$

Treba povedať, že existujú priame algoritmy (konečné, v princípe presné), ktoré riešia $Ax=b$ a príbuzné problémky na menej ako $O(n^3)$ operácií.

Príklad: násobenie dvoch $n \times n$ matíc (typický násobenie) ktoré potrebuje len 7 - 1969 Volker Strassen.

→ to viedie k zníženiu exponentu 3 na $\log_2(7) \approx 2.87$

Následne: (Coppersmith-Winograd ≈ 2.376)

→ dôvera tieto algoritmy nie sú praktické, keď budú viedieť 3 a 2.87 je malý alebo veľkosť n , keď sa opäť prejde z $O(n^3)$ na $O(n^{2.376})$ je astronomická pre súčasné počítače.

Budúcnosť? Násobenie matíc za $O(n^2)$?

alebo viacne $Ax=b$ za $n^2 \log(n)$?

"Fast inverse"?