

# *Numerička matematika*

## *4. predavanje*

Saša Singer

`singer@math.hr`

`web.math.hr/~singer`

PMF – Matematički odjel, Zagreb

# Sadržaj predavanja

- Rješavanje linearnih sustava:
  - Pivotiranje u LR (LU) faktorizaciji.
  - Teorija perturbacije linearnih sustava.
  - Hilbertove matrice.
  - Uloga reziduala i iterativno poboljšanje rješenja.
  - Struktura LR (LU) faktorizacije.
  - Matrice za koje ne treba pivotiranje.
  - Simetrične pozitivno definitne matrice.
  - Faktorizacija Choleskog.
  - Pivotiranje u faktorizaciji Choleskog.

# Informacije

Sljedeći petak **nema** nastave (Bush). Nadoknada sljedi ...  
Može li **utorak**, 8. 4., od **16–19**?

Termin **prvog kolokvija** je:

🕒 **ponedjeljak**, 28. 4., u **12** sati.

Moja **web stranica** za **Numeričku matematiku** je

[http://web.math.hr/~singer/num\\_mat/](http://web.math.hr/~singer/num_mat/)

Materijale za predavanja doc. **Grubišića** možete naći na

<http://web.math.hr/~luka/indexh.html>

# Veza Gaussovih eliminacija i LR faktorizacije

Može se pokazati da je

- matrica  $R$  dobivena LR faktorizacijom **jednaka**
- matrici  $R$  dobivenoj Gausovim eliminacijama.

Neka je matrica

- $A^{(k)}$  dobivena u  $k$ -tom koraku Gaussovih eliminacija,
- a  $A^{(k+1)}$  matrica iz sljedećeg koraka.

Onda se  $A^{(k+1)}$  može **matrično** napisati kao produkt

$$A^{(k+1)} = M_k A^{(k)},$$

pri čemu je ...

# Veza Gaussovih eliminacija i LR faktorizacije

$$M_k = \left[ \begin{array}{c|cccc} I_{k-1} & & & & \\ \hline & 1 & & & \\ & -m_{k+1,k} & 1 & & \\ & -m_{k+2,k} & & \ddots & \\ & \vdots & & & \ddots \\ & -m_{n,k} & & & 1 \end{array} \right]$$

a  $m_{ik}$  su odgovarajući **multiplikatori**.

Na kraju eliminacija, nakon  $n$  koraka, dobijemo trokutasti  $\tilde{R}$ ,

$$\tilde{R} := A^{(n)} = M_{n-1} M_{n-2} \cdots M_1 A.$$

# Veza Gaussovih eliminacija i LR faktorizacije

Svi  $M_k$  regularni, jer su  $M_k$  donje trokutaste s 1 na dijagonali, pa postoje njihovi inverzi.

$A$  se može napisati kao  $A = M_1^{-1} M_2^{-1} \cdots M_{n-1}^{-1} \tilde{R} := \tilde{L} \tilde{R}$ , gdje je

$$\tilde{L} = \begin{bmatrix} 1 & & & & & \\ m_{21} & 1 & & & & \\ \vdots & m_{32} & \ddots & & & \\ \vdots & \vdots & & \ddots & & \\ m_{n1} & m_{n2} & \cdots & m_{n,n-1} & 1 & \end{bmatrix}.$$

Iz **jedinstvenosti** LR faktorizacije slijedi da je  $\tilde{R} = R$ .

## Parcijalno pivotiranje u LR faktorizaciji

Veza LR faktorizacije i Gaussovih eliminacija upućuje nas da pivotiranje vršimo **na isti način** kao kod Gaussovih eliminacija.

Ako koristimo **parcijalno pivotiranje**, onda se LR faktorizacija tako dobivene matrice (permutiranih redaka) zapisuje kao

$$PA = LR,$$

pri čemu je  $P$  **matrica permutacije**.

**Matrica permutacije** ima u **svakom retku** i **stupcu** ima točno jednu jedinicu, a ostalo su nule.  $P$  je uvijek regularna matrica — pokažite to!

## Parcijalno pivotiranje u LR faktORIZACIJI

Ako znamo “permutiranu” faktORIZACIJU, kako ćemo riješiti sustav  $Ax = b$ ?

Najjednostavnije je lijevu i desnu stranu (slijeva) pomnožiti s  $P$ , pa dobivamo

$$PAx = LRx = Pb.$$

**Oprez:** kad permutiramo, istovremeno zamjenjujemo retke i od  $L$  i od  $R$ .

Kako realiziramo permutacije u algoritmu?



# Parcijalno pivotiranje u LR faktorizaciji

## Realizacija permutacija:

- fizički zamjenjujemo retke u radnoj matrici  $A$  u kojoj formiramo  $L$  i  $R$ ,
- moramo pamtiti permutaciju  $P$  (zbog permutacije desne strane,  $b$ ),
- $P$  se pamti kao vektor  $p$  koji na mjestu  $i$  ima indeks stupca gdje se nalazi jedinica u  $i$ -tom retku od  $P$ .

# Parcijalno pivotiranje u LR faktorizaciji

**Primjer.** Ako u LR faktorizaciji sustava s 3 jednačbe zamijenimo

prvi i treći redak,

pa onda trenutni drugi i treći redak,

onda će se  $P$ , odnosno  $p$  mijenjati ovako:

$$P : \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \rightarrow \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix} \rightarrow \begin{bmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix},$$

$$p : \begin{bmatrix} 1 \\ 2 \\ 3 \end{bmatrix} \rightarrow \begin{bmatrix} 3 \\ 2 \\ 1 \end{bmatrix} \rightarrow \begin{bmatrix} 3 \\ 1 \\ 2 \end{bmatrix}.$$

## Potpuno pivotiranje u LR faktorizaciji

Ako koristimo **potpuno pivotiranje**, dobivamo LR faktorizaciju matrice koja ima **permutirane** retke i stupce obzirom na  $A$ , tj.

$$PAQ = LR,$$

gdje su  $P$  i  $Q$  matrice permutacije.

**Skica rješenja.**  $Q$  je unitarna, pa iz  $PA = LRQ^T$ , uz pokratu  $Q^T x = z$ , imamo

$$PAx = LR(Q^T x) = LRz = Pb,$$

što znači da je jedina razlika obzirom na **parcijalno pivotiranje** na kraju “**izokretati**” rješenje  $x$ .

# Parcijalno vs. potpuno pivotiranje

Možemo li i na temelju čega reći da je potpuno pivotiranje “bolje” od parcijalnog? Tradicionalno to se čini na temelju pivotnog rasta.

Pivotni rast (ili “faktor rasta”) je omjer

- najvećeg (po apsolutnoj vrijednosti) elementa u svim koracima eliminacije,
- i najvećeg elementa u originalnoj matrici

$$\rho_n = \frac{\max_{i,j,k} |a_{ij}^{(k)}|}{\max_{i,j} |a_{ij}|}.$$

Intuitivno je jasno da nije dobro da elementi rastu po apsolutnoj vrijednosti, jer bi to moglo dovesti do gubitka točnosti.

# Pivotni rast

Koliki je **pivotni rast** kod **parcijalnog** pivotiranja?

Korištenjem relacija za **ponišćavanje elemenata**

$$a_{ij}^{(k+1)} = a_{ij}^{(k)} - m_{ik}a_{kj}^{(k)}, \quad |m_{ik}| \leq 1,$$

za **parcijalno pivotiranje** vrijedi

$$|a_{ij}^{(k+1)}| \leq |a_{ij}^{(k)}| + |a_{kj}^{(k)}| \leq 2 \max_{i,j} |a_{ij}^{(k)}|.$$

Prethodna ocjena, za  $n$  koraka algoritma daje **pivotni rast**  $\rho_n^p$

$$\rho_n^p \leq 2^{n-1}.$$

## Pivotni rast

Već je J. Wilkinson primijetio da se taj pivotni rast **može doći** za sve matrice oblika

$$\begin{bmatrix} 1 & & & & 1 \\ -1 & 1 & & & 1 \\ -1 & -1 & \ddots & & 1 \\ -1 & -1 & \ddots & 1 & 1 \\ -1 & -1 & -1 & -1 & 1 \end{bmatrix}.$$

**Eksponencijalno** rastu elementi **posljednjeg** stupca.

Ovo je samo “**umjetno**” konstruirani primjer, a u praksi je takvih matrica **izrazito malo**, pa se parcijalno pivotiranje ponaša **mного bolje** od očekivanog.

## Pivotni rast

Za **potpuno pivotiranje** pivotni rast  $\rho_n^c$  može se **ogradi**ti odozgo s

$$\rho_n^c \leq n^{1/2} (2 \cdot 3^{1/2} \dots n^{1/(n-1)})^{1/2} \approx c n^{1/2} n^{(\log n)/4},$$

ali ta ograda **nije dostižna**. Ovo je dokazao J. H. Wilkinson, šezdesetih godina prošlog stoljeća.

Dugo se mislilo da vrijedi

$$\rho_n^c \leq n,$$

međutim **nađeni** su primjeri matrica kad to ne vrijedi.

**Kontraprimjer** konstruiran 1991., matrice reda **13** ima pivotni rast  $\rho_n^c = 13.0205$ .

# Teorija perturbacije linearnih sustava

Teorija perturbacije linearnih sustava bavi se **ocjenom** (po elementima i/ili po normi) koliko se **najviše** promijeni rješenje sustava  $x$  ako se malo promijene elementi  $A$  i/ili  $b$ .

**Problem.** Neka je

$$Ax = b,$$

$A \in \mathbb{F}^{n \times n}$  regularna, a  $b$  zadani vektor.

Zanima nas koliko će se **najviše** promijeniti rješenje problema  $x$  ako **perturbiramo**  $A$ , odnosno  $b$ .

- Pojednostavnimo problem i pretpostavimo da je  $A$  **fiksna** matrica, a dozvoljene su perturbacije samo vektora  $b$ .



# Koliko je dobro uvjetovan linearni sustav?

Za prethodni problem

- ulazni podaci su elementi od  $A$  i  $b$  (njih  $n^2 + n$ ), a rezultat je vektor  $x \in \mathbb{F}^n$ , a
- pripadna funkcija problema je  $f : \mathbb{F}^n \rightarrow \mathbb{F}^n$  je

$$x = f(b) := A^{-1}b.$$

Iz prethodnog predavanja znamo da je relativna uvjetovanost problema (samo umjesto  $x$  pišemo  $b$ )

$$\kappa_{\text{rel}}(b) = (\text{cond } f)(b) := \left| \frac{bf'(b)}{f(b)} \right|.$$

## Koliko je dobro uvjetovan linearni sustav?

Za višedimenzionalne probleme, da bismo dobili **jedan broj** u prethodnoj formuli, uzmemo **normu**, a derivacija je **gradijent**,

$$\nabla f(b) = A^{-1},$$

pa je

$$\kappa_{\text{rel}}(b) = \frac{\|b\|_2 \|A^{-1}\|_2}{\|A^{-1}b\|_2} = \frac{\|Ax\|_2 \|A^{-1}\|_2}{\|x\|_2}.$$

Gledamo **najgoru** moguću uvjetovanost:

$$\max_{\substack{b \in \mathbb{F}^n \\ b \neq 0}} \kappa_{\text{rel}}(b) = \max_{\substack{x \in \mathbb{F}^n \\ x \neq 0}} \frac{\|Ax\|_2}{\|x\|_2} \|A^{-1}\|_2 = \|A\|_2 \|A^{-1}\|_2.$$

# Primjer

Za mjeru uvjetovanosti sustava, možemo uzeti:

$$\text{cond } A := \|A\|_2 \|A^{-1}\|_2.$$

Ako je uvjetovanost mala, mora li onda rješenje računalom biti dobro?

Primjer. Sjetimo se sustava  $Ax = b$ , gdje je

$$A = \begin{bmatrix} 0.0001 & 1 \\ 1 & 1 \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 2 \end{bmatrix}.$$

Za vježbu izračunajte da je

$$\text{cond } A \approx 2.6183852736548268689.$$

## Primjer

Je li to dobro uvjetovan sustav? **Jest!**

**Digresija.** Nije teško pokazati da za regularne matrice vrijedi

$$1 = \|A \cdot A^{-1}\| \leq \|A\|_2 \|A^{-1}\|_2 = \text{cond}(A)$$

a jednakost se dostiže za **unitarne matrice**. Uvjetovanost je loša ako je  **$\text{cond}(A) \gg 1$** . ■

U prethodnom sustavu je nešto **pošlo po zlu**? Što?

Na **bitnom mjestu** u računu došlo je do “**underflow-a**” (mali broj je pretvoren u nulu) i više ne možemo govoriti o **malim relativnim perturbacijama**.

# Hilbertova matrica

**Primjer.** Kod aproksimacije polinomima javljaju se linearni sustavi oblika

$$H_n x = b,$$

gdje je  $H_n$  Hilbertova matrica reda  $n$ , tj.

$$H_n = \begin{bmatrix} 1 & \frac{1}{2} & \cdots & \frac{1}{n} \\ \frac{1}{2} & \frac{1}{3} & \cdots & \frac{1}{n+1} \\ \vdots & \cdots & \ddots & \vdots \\ \frac{1}{n} & \frac{1}{n+1} & \cdots & \frac{1}{2n-1} \end{bmatrix}.$$

# Hilbertova matrica

Da bismo ispitali točnost rješenja, stavimo

$$b(i) := \sum_{j=1}^n H_n(i, j),$$

tako da je rješenje sustava  $x^T = [1, 1, \dots, 1]$ .

Što možemo očekivati od rješenja takvog sustava?

Pogled na **Frobeniusovu normu** matrice  $A$  kaže da ona **nije naročito velika**, tj.

$$\|H_n\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n \left| \frac{1}{i+j-1} \right|} \leq \sqrt{\sum_{i=1}^n \sum_{j=1}^n 1} = n.$$

# Hilbertova matrica

Međutim ... ne treba gledati samo normu matrice!!!

Uvjetovanost Hilbertovih matrica je vrlo visoka:

$n$	$\kappa_2(H_n)$	$n$	$\kappa_2(H_n)$	$n$	$\kappa_2(H_n)$
2	$1.928 \cdot 10^1$	9	$4.932 \cdot 10^{11}$	15	$6.117 \cdot 10^{20}$
3	$5.241 \cdot 10^2$	10	$1.603 \cdot 10^{13}$	16	$2.022 \cdot 10^{22}$
4	$1.551 \cdot 10^4$	11	$5.231 \cdot 10^{14}$	17	$6.697 \cdot 10^{23}$
5	$4.766 \cdot 10^5$	12	$1.713 \cdot 10^{16}$	18	$2.221 \cdot 10^{25}$
6	$1.495 \cdot 10^7$	13	$5.628 \cdot 10^{17}$	19	$7.376 \cdot 10^{26}$
7	$4.754 \cdot 10^8$	14	$1.853 \cdot 10^{19}$	20	$2.452 \cdot 10^{28}$
8	$1.526 \cdot 10^{10}$				

## Hilbertova matrica — $n = 2, 5$

Za sustav s Hilbertovom matricom, u **extended** točnosti, umjesto svih **jedinica** u rješenju, dobivamo:

Red 2

$$x(1) = 1.0000000000000000 \quad x(2) = 1.0000000000000000$$

Red 5

$$x(1) = 1.0000000000000000 \quad x(4) = 0.99999999999999990$$

$$x(2) = 0.9999999999999999 \quad x(5) = 1.00000000000000005$$

$$x(3) = 1.00000000000000007$$



## Hilbertova matrica — $n = 10$

$$x(1) = 1.0000000000000003436$$

$$x(6) = 0.9999999294831902$$

$$x(2) = 0.9999999999710395$$

$$x(7) = 1.0000001151701616$$

$$x(3) = 1.0000000006068386$$

$$x(8) = 0.9999998890931838$$

$$x(4) = 0.9999999945453735$$

$$x(9) = 1.0000000580638087$$

$$x(5) = 1.0000000258066880$$

$$x(10) = 0.9999999872591526$$

Uvjetovanost:  $\approx 1.603 \cdot 10^{13}$ .

## Hilbertova matrica — $n = 15$

$$x(1) = 1.00000000005406387 \quad x(9) = 1.0952919444304200$$

$$x(2) = 0.99999999069805858 \quad x(10) = 0.8797820363884070$$

$$x(3) = 1.0000039790948573 \quad x(11) = 1.0994671444236333$$

$$x(4) = 0.9999257525660447 \quad x(12) = 0.9508102511158300$$

$$x(5) = 1.0007543452271621 \quad x(13) = 1.0106027108940050$$

$$x(6) = 0.9953234190795597 \quad x(14) = 1.0012346841153261$$

$$x(7) = 1.0188643674562383 \quad x(15) = 0.9992252029377023$$

$$x(8) = 0.9487142544341838$$

Uvjetovanost:  $\approx 6.117 \cdot 10^{20}$ .

## Hilbertova matrica — $n = 20$

$x(1) =$	1.0000000486333029	$x(11) =$	231.3608002738048500
$x(2) =$	0.9999865995557111	$x(12) =$	-60.5143391625873562
$x(3) =$	1.0008720556363132	$x(13) =$	-57.6674972682886125
$x(4) =$	0.9760210562677670	$x(14) =$	5.1760567992057506
$x(5) =$	1.3512820600312678	$x(15) =$	8.7242780841976215
$x(6) =$	-2.0883247796748707	$x(16) =$	210.1722288687690970
$x(7) =$	18.4001541798146106	$x(17) =$	-413.9544667202651170
$x(8) =$	-63.8982130462650081	$x(18) =$	349.7671855031355400
$x(9) =$	161.8392478869777220	$x(19) =$	-142.9134532513063250
$x(10) =$	-254.7902985140752950	$x(20) =$	25.0584794423327874

Uvjetovanost  $\approx 2.452 \cdot 10^{28}$ .

## Hilbertova matrica

Recimo,  $H_5^{-1}$  izgleda ovako:

$$H_5^{-1} = \begin{bmatrix} 25 & -300 & 1050 & -1400 & 630 \\ -300 & 4800 & -18900 & 26880 & -12600 \\ 1050 & -18900 & 79380 & -117600 & 56700 \\ -1400 & 26880 & -117600 & 179200 & -88200 \\ 630 & -12600 & 56700 & -88200 & 44100 \end{bmatrix} .$$

A kako tek izgledaju elementi  $H_{20}^{-1}$ ?

## Još malo o perturbacijama linearnih sustava

Ocjenu koliko se **najviše** promijenilo rješenje sustava  $Ax = b$  možemo dobiti i **direktno** i to po **elementima/normi**

- ako perturbiramo **samo**  $A$  ili **samo**  $b$ ,
- ako perturbiramo **i**  $A$  **i**  $b$ .

Pretpostavimo da smo perturbirali **samo**  $A$ . Umjesto sustava  $Ax = b$  tada rješavamo

$$(A + \Delta A)(x + \Delta x) = b.$$

Također, možemo pretpostaviti da za **operatorsku normu perturbacije** vrijedi

$$\|\Delta A\| \leq \varepsilon \|A\|.$$

**Komentar.** Ako je  $\varepsilon$  točnost računanja, tolika perturbacija **napravljena** već pri **spremanju** elemenata matrice u računalo.

## Perturbacija matrice $A$

Oduzimanjem  $Ax = b$  od  $(A + \Delta A)(x + \Delta x) = b$  dobivamo

$$A \Delta x + \Delta A (x + \Delta x) = 0.$$

Množenjem slijeva s  $A^{-1}$  i sređivanjem dobivamo

$$\Delta x = -A^{-1} \Delta A (x + \Delta x).$$

Uzimanjem norme lijeve i desne strane, a zatim **ocjenjivanjem odozgo**, dobivamo

$$\begin{aligned} \|\Delta x\| &\leq \|A^{-1}\| \|\Delta A\| \|x + \Delta x\| \leq \varepsilon \|A^{-1}\| \|A\| \|x + \Delta x\| \\ &\leq \varepsilon \kappa(A) (\|x\| + \|\Delta x\|), \end{aligned}$$

pri čemu je  $\kappa(A) = \|A\| \|A^{-1}\|$  uvjetovanost matrice  $A$ .

## Perturbacija matrice $A$

Premještanjem na lijevu stranu svih pribrojnika koji sadrže  $\Delta x$  dobivamo

$$(1 - \varepsilon \kappa(A)) \|\Delta x\| \leq \varepsilon \kappa(A) \|x\|.$$

Ako je  $\varepsilon \kappa(A) < 1$ , a to znači i  $\|\Delta A\| \|A^{-1}\| < 1$ , onda je

$$\|\Delta x\| \leq \frac{\varepsilon \kappa(A)}{1 - \varepsilon \kappa(A)} \|x\|,$$

što pokazuje da je **pogreška** u rješenju približno **proporcionalna uvjetovanosti** matrice  $A$ .

## Perturbacija vektora $b$

Pretpostavimo sad da, umjesto sustava  $Ax = b$  rješavamo

$$A(x + \Delta x) = b + \Delta b.$$

Ponovno pretpostavljamo da je **operatorska norma perturbacije** vektora  $b$

$$\|\Delta b\| \leq \varepsilon \|b\|.$$

**Oduzimanjem**  $Ax = b$  od  $A(x + \Delta x) = b + \Delta b$  izlazi

$$A \Delta x = \Delta b.$$

**Množenjem** slijeva s  $A^{-1}$  dobivamo

$$\Delta x = A^{-1} \Delta b.$$



## Perturbacija vektora $b$

Uzimanjem norme lijeve i desne strane, a zatim **ocjenjivanjem odozgo**, dobivamo

$$\begin{aligned}\|\Delta x\| &\leq \|A^{-1}\| \|\Delta b\| \leq \varepsilon \|A^{-1}\| \|b\| \leq \varepsilon \|A^{-1}\| \|Ax\| \\ &\leq \varepsilon \|A^{-1}\| \|A\| \|x\| \leq \varepsilon \kappa(A) \|x\|,\end{aligned}$$

što pokazuje da je **pogreška** u rješenju, ponovno, **proporcionalna uvjetovanosti** matrice  $A$ .

Sada možemo **generalizirati** rezultat ako **perturbiramo** istovremeno i  $A$  i  $b$ .

# Perturbacija $i$ $A$ $i$ $b$

**Teorem.** Neka je  $Ax = b$  i

$$(A + \Delta A)(x + \Delta x) = b + \Delta b,$$

gdje je  $\|\Delta A\| \leq \varepsilon \|E\|$ ,  $\|\Delta b\| \leq \varepsilon \|f\|$ , pri čemu je  $E$  neka matrica, a  $f$  neki vektor. Također, neka je  $\varepsilon \|A^{-1}\| \|E\| < 1$ . Tada za  $x \neq 0$  vrijedi

$$\frac{\|\Delta x\|}{\|x\|} \leq \frac{\varepsilon}{1 - \varepsilon \|A^{-1}\| \|E\|} \left( \frac{\|A^{-1}\| \|f\|}{\|x\|} + \|A^{-1}\| \|E\| \right).$$

## Perturbacija $i$ $A$ $i$ $b$

**Komentar:** Uobičajeno se za  $E$  uzima  $A$ , jer je to **pogreška** koju napravimo spremanjem matrice  $A$  u računalo. Jednako tako, za  $f$  se uzima  $b$ . U tom slučaju je

$$\begin{aligned}\frac{\|\Delta x\|}{\|x\|} &\leq \frac{\varepsilon}{1 - \varepsilon \|A^{-1}\| \|A\|} \left( \frac{\|A^{-1}\| \|b\|}{\|x\|} + \|A^{-1}\| \|A\| \right) \\ &= \frac{\varepsilon}{1 - \varepsilon \kappa(A)} \left( \frac{\|A^{-1}\| \|Ax\|}{\|x\|} + \kappa(A) \right) \\ &\leq \frac{\varepsilon}{1 - \varepsilon \kappa(A)} \left( \frac{\|A^{-1}\| \|A\| \|x\|}{\|x\|} + \kappa(A) \right) \\ &= \frac{2\varepsilon \kappa(A)}{1 - \varepsilon \kappa(A)}.\end{aligned}$$

# Perturbacija $A$ i $b$

**Dokaz.** Provodi se na sličan način kao za pojedinačne perturbacije.

Ako oduzmemo  $Ax = b$  od obje strane  $(A + \Delta A)(x + \Delta x) = b + \Delta b$ , dobivamo

$$A \Delta x = \Delta b - \Delta A x - \Delta A \Delta x.$$

Množenjem s  $A^{-1}$  slijeva, a zatim korištenjem svojstva **operatorskih normi**, lako izlazi traženo. ■

# Uloga reziduala

Kad smo računali računalom, umjesto pravog rješenja sustava  $x$ , dobili smo približno,  $\hat{x}$ .

Veličinu

$$r = b - A\hat{x},$$

zovemo rezidual rješenja.

Rezidual pravog rješenja  $x$  je  $r = 0$ !

Međutim, ako je rezidual

- velik, onda sigurno nismo blizu pravom rješenju,
- ali rezidual može biti malen, a da izračunato rješenje sustava nije niti blizu pravom.

# Uloga reziduala

Primjer. Za sustav

$$H_{20}x = b$$

izračunat u **extended** točnosti, s desnom stranom takvom da je  $x^T = [1, 1, \dots, 1]$

• rezidual je **nula-vektor**,

a komponente rješenja su bile u **stotinama**.

# Uloga reziduala

Reziduali se obično koriste za **poboljšavanje** netočnog rješenja linearnog sustava.

To se obično provodi u **tri** koraka.

- 1. Izračuna se rezidual  $r = b - A\hat{x}$ , pri čemu je  $\hat{x}$  **izračunato** rješenje sustava.
- 2. Riješi se sustav  $Ad = r$ , gdje je  $d$  korekcija.
- 3. Korekcija se dodaje izračunatom rješenju

$$y = \hat{x} + d,$$

što bi trebalo dati bolje rješenje.


# Struktura LR faktorizacije

Ako matrica  $A$  koja ulazi u LR faktorizaciju ima nekakvu **strukturu**, pitanje je kad će se ta struktura **sačuvati**.

To je **posebno bitno** za

- sustave gdje je  $A$  takva da se **bitna** informacija o njoj može spremiti u **bitno manje** od  $n^2$  elemenata.

Ako **ne pivotiramo**, onda se čuvaju, recimo, sljedeće forme:





## Kad ne moramo pivotirati?

**Odgovor.** Postoje tipovi matrica kad **ne moramo** pivotirati.  
Na primjer, to su:

- dijagonalno dominantne matrice po stupcima, tj. matrice za koje vrijedi

$$|a_{jj}| > \sum_{\substack{i=1 \\ i \neq j}}^n |a_{ij}|,$$

- dijagonalno dominantne matrice po redcima,
- simetrične pozitivno definitne matrice — o njima malo kasnije.

## Kad ne moramo pivotirati?

Za **dijagonalno dominantne matrice** po stupcima treba samo pokazati da iza **prvog koraka** eliminacije **ostaju** dijagonalno dominantne po stupcima.

1. **Zaključak.**  $a_{11} \neq 0$  i maksimalan po apsolutnoj vrijednosti u 1. stupcu, pa sigurno možemo napraviti 1. korak eliminacije.

Dobivamo matricu  $A^{(2)}$  oblika

$$A^{(2)} = \begin{bmatrix} a_{11} & a_1 \\ 0 & S \end{bmatrix},$$

pri čemu je  $S$  **regularna** (dokaz korištenjem determinanti).

2. **Korak.** Moramo pokazati da je matrica  $S$  **dijagonalno dominantna** po stupcima.

## Kad ne moramo pivotirati?

Za  $j = 2, \dots, n$  vrijedi

$$\sum_{\substack{i=2 \\ i \neq j}}^n |a_{ij}^{(2)}| = \sum_{\substack{i=2 \\ i \neq j}}^n \left| a_{ij} - \frac{a_{i1} a_{1j}}{a_{11}} \right| \leq \sum_{\substack{i=2 \\ i \neq j}}^n |a_{ij}| + \left| \frac{a_{1j}}{a_{11}} \right| \sum_{\substack{i=2 \\ i \neq j}}^n |a_{i1}|$$

(dijagonalna dominantnost obje sume)

$$< (|a_{jj}| - |a_{1j}|) + \left| \frac{a_{1j}}{a_{11}} \right| (|a_{11}| - |a_{j1}|)$$

$$= |a_{jj}| - \left| \frac{a_{1j}}{a_{11}} a_{j1} \right| \quad (\text{koristimo } |a| - |b| \leq |a - b|)$$

$$\leq \left| a_{jj} - \frac{a_{1j}}{a_{11}} a_{j1} \right| = |a_{jj}^{(2)}|,$$

što pokazuje da je i  $A^{(2)}$  dijagonalno dominantna po stupcima.

# Simetrične pozitivno definitne matrice

Za simetrične/hermitske pozitivno definitne matrice radi se “simetrizirana varijanta” LR faktorizacije

- jer je 2 puta brža nego obična LR faktorizacija,
- čuva strukturu matrice  $A$  – čak i kad računamo u strojnoj aritmetici množenjem faktora uvijek dobivamo simetričnu matricu.

“Simetrizirana LR” faktorizacija zove se faktorizacija Choleskog.

Prisjećanje. Matrica je hermitska ako je

$$A = A^*.$$

Ako je  $A \in \mathbb{R}^{n \times n}$ , onda je hermitska matrica isto što i simetrična, tj.  $*$  =  $T$ .

# Simetrične pozitivno definitne matrice

Pozitivna definitnost matrice se ne vidi odmah. Uobičajeno se unaprijed, iz prirode problema zna da je neka matrica pozitivno definitna.

Matrica  $A \in \mathbb{F}^{n \times n}$  je pozitivno definitna ako je

$$x^* Ax > 0 \quad \text{za svaki } x \neq 0, \quad x \in \mathbb{F}^n.$$

Ekvivalentni uvjeti za pozitivnu definitnost:

☛ sve svojstvene vrijednosti od  $A$  su pozitivne, tj. vrijedi

$$\lambda_k(A) > 0, \quad \text{za } k = 1, \dots, n,$$

gdje  $\lambda_k$  označava  $k$ -tu najveću svojstvenu vrijednost;

# Simetrične pozitivno definitne matrice

Ekvivalentni uvjeti (nastavak):

- ☛ sve vodeće glavne minore od  $A$  su pozitivne, tj. vrijedi

$$\det(A_k) > 0, \quad \text{za } k = 1, \dots, n,$$

gdje je  $A_k = A(1 : k, 1 : k)$  vodeća glavna podmatrica od  $A$  reda  $k$ .

**Digresija.** Katkad se puno lakše vidi da neka matrica nije pozitivno definitna. Pokažite da nisu pozitivno definitne matrice koje

- ☛ na dijagonali imaju negativan element ili nulu.

# Faktorizacija Choleskog

Iz ekvivalentnog uvjeta odmah izlazi da za hermitsku/simetričnu pozitivno definitnu matricu uvijek može napraviti LR faktorizacija bez pivotiranja (v. Teorem)!

Tvrdnja. Za hermitsku/simetričnu pozitivno definitnu matricu  $A$ , LR faktorizaciju možemo napisati u obliku

$$A = LDL^*.$$

Ta faktorizacija se obično zove  $LDL^*$  faktorizacija.

U LR faktorizaciji matrice  $A$  faktor  $R$  rastavi se na

$$R = DM^*$$

$D$  dijagonalna,  $M^*$  gornjetrokutasta s jedinicama na dijagonali.

# Faktorizacija Choleskog

Da se dobije takva faktorizacija,

- dijagonalni elementi  $R$  stave se na dijagonalu od  $D$ ,
- svaki redak u  $R$  podijeli se s dijagonalnim elementom u tom retku da se dobije  $M^*$ .

Dakle,

$$A = LDM^*, \quad M \text{ donjetrokutasta, regularna.}$$

Zbog hermitičnosti/simetrije vrijedi

$$A = A^* = (LDM^*)^* = MDL^*,$$

pa je  $LDM^* = MDL^* \dots$



# Faktorizacija Choleskog

(nastavak) ...

$$LDM^* = MDL^*.$$

Množenjem slijeva s  $L^{-1}$  i zdesna s  $L^{-*}$  dobivamo

$$DM^*L^{-*} = L^{-1}MD.$$

Na lijevoj strani imamo produkt **gornjetrokutastih** matrica, a na desnoj strani **donjetrokutastih**, pa su ti produkti **dijagonalne matrice**.

Te dijagonalne matrice su **jednake**  $D$  (jer i  $M$  i  $L$  imaju na dijagonali **jedinice**), pa je

$$L^{-1}MD = D \implies MD = LD \implies M = L.$$

# Faktorizacija Choleskog

Nadalje,  $D$  ima **pozitivne elemente**, jer bi inače postojao vektor  $x$  takav da je

$$(Ax, x) = (LDL^*x, x) = (DL^*x, L^*x) := (Dy, y) \leq 0.$$

Dakle,  $D$  možemo **rastaviti** na

$$D = \Delta \cdot \Delta$$

gdje je  $\Delta$  **dijagonalna** i  $\Delta_{ii} = \sqrt{D_{ii}}$ .

Tada  $LDL^*$  faktorizaciju možemo napisati u obliku:

$$A = LDL^* = (L\Delta)(\Delta L^*) = (L\Delta)(\Delta^*L^*) = (L\Delta)(L\Delta)^*.$$

# Faktorizacija Choleskog

Uz oznaku  $R := (L\Delta)^*$  dobivamo faktorizaciju Choleskog

$$A = R^*R.$$

**Digresija.** Mnogi slovom  $L$  označavaju  $L := L\Delta$ , pa se u literaturi faktorizacija Choleskog može naći napisana kao

$$A = LL^*.$$

**Oprez:** taj  $L$  nema jedinice na dijagonali!

Kad znamo da postoji, **Faktorizacija Choleskog** se može i **direktno** izvesti, znajući da je  $A = R^*R$ .

# Algoritam

Ograničimo se na **realni** slučaj. Tada je

$$a_{ij} = \sum_{k=1}^i r_{ki} r_{kj}, \quad i \leq j,$$

pa dobivamo sljedeću **rekurziju** za elemente:

za  $j = 1, \dots, n$  :

$$r_{ij} = \left( a_{ij} - \sum_{k=1}^{i-1} r_{ki} r_{kj} \right) / r_{ii}, \quad i = 1, \dots, j-1,$$

$$r_{jj} = \left( a_{jj} - \sum_{k=1}^{j-1} r_{kj}^2 \right)^{1/2}.$$

Za  $j = 1$  računamo samo  $r_{11}$ .

**Greške zaokruživanja**  $\Rightarrow$  moguć **negativan** izraz pod korijenom.

# Algoritam

## Faktorizacija Choleskog

```
za j = 1 do n radi {  
    /* Nađi j-ti stupac od R */  
    /* Supstitucija unaprijed iznad dijagonale */  
    za i = 1 do j - 1 radi {  
        sum = A[i, j];  
        za k = 1 do i - 1 radi {  
            sum = sum - R[k, i] * R[k, j];  
        };  
        R[i, j] = sum / R[i, i];  
    };  
};
```

# Algoritam

```
/* Dijagonalni element */
sum = A[j, j];
za k = 1 do j - 1 radi {
    sum = sum - R[k, j]**2;
};
ako je sum > 0.0 onda {
    R[j, j] = sqrt(sum)
};
inače
    /* Matrica nije pozitivno definitna, STOP */
};
```

# Komentar na algoritam

Uočimo da:

- se po prethodnoj rekurziji matrica  $R$  generira **stupac po stupac**, dok se u LR faktorizaciji  $R$  generirala **redak po redak**, a  $L$  **stupac po stupac**;
- ovo je tzv. *jik* varijanta algoritma, a naziv dolazi od **poretka petlji** uz prirodno imenovanje indeksa;
- ovo **nije** jedina varijanta za realizaciju algoritma.

**Složenost algoritma** (broj aritmetičkih operacija) je približno jednaka

$$OP(n) \sim \frac{1}{3} n^3,$$

što je približno **polovina** složenosti LR faktorizacije.

## Rješenje linearnog sustava

Kad imamo faktorizaciju Choleskog  $A = R^T R$ , onda se rješenje linearnog sustava  $Ax = b$  svodi na dva rješavanja trokutastih sustava

$$R^T y = b, \quad Rx = y,$$

koje lako rješavamo:

● sustav  $R^T y = b$  — supstitucijom unaprijed

$$y_1 = b_1 / r_{11}$$

$$y_i = \left( b_i - \sum_{j=1}^{i-1} r_{ji} y_j \right) / r_{ii}, \quad i = 2, \dots, n,$$



## Rješenje linearnog sustava

- sustav  $Rx = y$  — supstitucijom unatrag

$$x_n = y_n / r_{nn}$$

$$x_i = \left( y_i - \sum_{j=i+1}^n r_{ij} x_j \right) / r_{ii}, \quad i = n-1, \dots, 1.$$

Za **razliku** od LR faktorizacije, ovdje u obje supstitucije imamo dijeljenja.

Zbog toga se često koristi  $LDL^T$  oblik faktorizacije:

- u algoritmu **nema** računanja **drugih korijena**;
- rješavaju se **tri** linearna sustava:

$$Lz = b, \quad Dy = z, \quad L^T x = y.$$

- $L$  ima **jediničnu** dijagonalu, pa štedimo  $n$  **dijeljenja**.

## Može li $LDL^T$ za simetrične matrice?

Može li se  $LDL^T$  faktorizacija napraviti za bilo koju simetričnu matricu  $A$  (uz dozvolu da  $D$  ima i negativne elemente)?

To ne vrijedi! Kontraprimjer:

$$A = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix},$$

Pomaže li simetrična permutacija redaka/stupaca? Ne!

Poopćenje na indefinitne matrice dobivamo tako da dozvolimo dijagonalne blokove reda 2 u matrici  $D$ .

# Pivotiranje u faktORIZACIJI Choleskog

I kod faktORIZACIJE Choleskog možemo koristiti pivotiranje.

- Da bismo očuvali simetriju radne matrice, pivotiranje mora biti “simetrično”, tj. radimo istovremene zamjene redaka i stupaca u  $A$

$$A \rightarrow P^T A P,$$

gdje je  $P$  matrica permutacije.

- “Simetrična zamjena”  $\Rightarrow$  dijagonalni element zamjenjuje mjesto s dijagonalnim!
- Standardni izbor pivotnog elementa u  $k$ -tom koraku je

$$a_{rr}^{(k)} = \max_{k \leq i \leq n} a_{ii}^{(k)},$$

što odgovara potpunom pivotiranju u Gausovim eliminacijama.

# Pivotiranje u faktORIZACIJI Choleskog

Ovim postupkom dobivamo faktORIZACIJU Choleskog

$$P^T A P = R^T R,$$

a za elemente matrice  $R$  vrijedi

$$r_{kk}^2 \geq \sum_{i=k}^j r_{ij}^2, \quad j = k + 1, \dots, n, \quad k = 1, \dots, n.$$

Posebno, to znači da  $R$  ima nerastuću dijagonalu

$$r_{11} \geq \dots \geq r_{nn} > 0.$$